

PRISTUP MODELSKOM PREDIKTIVNOM UPRAVLJANJU KGH SUSTAVIMA U ZGRADAMA

Alan Rodić, mag. ing. mech.
Fakultet strojarstva i brodogradnje Sveučilišta u zagrebu
Ivana Lučića 5, 10000 Zagreb
01 6168 574
e-mail: alan.rodic@fsb.hr

SAŽETAK

Modelsko prediktivno upravljanje sustavima klimatizacije, grijanja, hlađenja i ventilacije u zgradama podrazumijeva skupinu metoda za napredno upravljanje kojim se parametri sustava grijanja i/ili hlađenja (ili drugih) zgrade optimiraju (obično svaki sat) za odabrani vremenski period (obično 24 sata), ovisno o predviđenim vremenskim uvjetima i načinu korištenja zgrade, prvenstveno s ciljem smanjenja ukupne potrošnje ili troškova energije uz istovremeno zadovoljavanje uvjeta toplinske ugodnosti. Optimizacija, odnosno optimizacijska funkcija kao dio naprednog upravljanja procesom temelji se na dinamičkom modelu koji opisuje toplinski odziv zgrade uzrokovan poremećajnim varijablama poput primjerice sunčevog zračenja, stanja okoliša i toplinskih dobitaka od ljudi i opreme. Ovom vrstom upravljanja otvaraju se mogućnosti za znatne uštede energije u sektoru zgradarstva koji je zaslužan za više od 40% ukupne potrošnje energije, kako u Europskoj uniji, tako i u ostatku razvijenog svijeta.

KLJUČNE RIJEČI

Modelsko prediktivno upravljanje, KGHV.

APPROACH TO MODEL PREDICTIVE CONTROL OF HVAC SYSTEMS IN BUILDINGS

Alan Rodić, mag. ing. mech.
Faculty of mechanical Engineering and Naval Architecture, University of
Zagreb
Ivana Lučića 5, 10000 Zagreb
01 6168 574
e-mail: alan.rodic@fsb.hr

ABSTRACT

Model Predictive Control in HVAC systems in Buildings comprehends a group of advanced control strategies aimed at optimizing the cooling and/or heating capacity for a predicted time horizon (usually 24h), depending on the future weather predictions and building usage, with the main goal to minimize energy consumption or energy costs while maintaining the optimal thermal comfort conditions. Optimization is based on a dynamic mathematical model of a building which describes the building's thermal response caused by heat disturbances such as outside weather conditions or heat gains from people and electrical equipment. Model predictive control offers the potential for extensive energy savings in the building sector which accounts for more than 40% of total energy consumption in the European Union as in the rest of the world.

KEY WORDS

Model Predictive Control, HVAC.

1. UVOD

Suvremeni poslovni objekti ili industrijska postrojenja odavno su prestali biti tek građevine u užem smislu riječi. Svakim danom zahtjevi i potrebe za raznovrsnim elektroničkim sustavima sve su veći. Bilo da je riječ o sustavima tehničke zaštite poput video nadzora ili kontrole pristupa, vatrozaštite ili detekcije plina, sustavima nadzora potrošnje električne energije ili pak specifičnim sustavima upravljanja, odnosno regulacije, pojavljuje se zajednički problem velikog broja raznolikih, međusobno odvojenih i prividno nekompatibilnih elektroničkih sustava. Neovisno o tome da li je riječ o zgradama s javnom ili poslovnom namjenom ili se radi o industrijskom procesu, koncept središnjeg upravljanja je jednak i poznat pod zajedničkim nazivom centralni nadzorno–upravljački sustav (u daljnjem tekstu CNUS). Prema definiciji, sustav automatike i upravljanja u zgradarstvu obuhvaća sve proizvode i tehničke usluge za automatsko upravljanje i kontrolu (nadzor), optimizaciju, interakciju s ljudima te održavanje, odnosno menadžment objekta, kojima je svrha postizanje pouzdanih, energetske učinkovitih, ekonomičnih i za uporabu sigurnih sustava u zgradama [1, 2]. Pri tome se za svaku pojedinu zgradu prikupljaju i obrađuju informacije potrebne za upravljanje, dok se podaci arhiviraju i vizualiziraju prema potrebama korisnika. Najčešće se automatiziraju instalacije sustava klimatizacije, grijanja, hlađenja i ventilacije (u daljnjem tekstu KGHV), odnosno toplinske i rashladne stanice, klimatizacijski uređaji i ventilatorske jedinice, ogrjevnja i rashladna tijela poput ventilokonvektora i sl. te elektrotehničke grupe sustava kao primjerice nadzor i upravljanje razvodnim ormarima električne energije, rasvjeta, agregati, dizala, alarmni sustavi i sl.

Upravljački sustavi u zgradama u prošlosti nisu bili opskrbljeni dovoljnom količinom informacija za korisnika o radu postojeće opreme i sustava, a upravitelji, odnosno služba održavanja često su previđali cjenovno optimalne mogućnosti za obnovu zgrada te je optimizacija rada sustava u realnom vremenu bila je gotovo nezamisliva. Posljednjih desetljeća, opseg CNUS-a širi se u smislu prikupljanja informacija od raznih sustava u zgradi, s ciljem razvoja tzv. inteligentnih zgrada. Danas su CNUS-i znatno većih kapaciteta i robusnije podatkovne strukture koja omogućava kontinuirano mjerenje parametara rada sustava, podržava određenu obradu podataka te pruža mogućnost njihove djelomične analize i vizualizacije. Međutim, osnovni problem modernih sustava u zgradama

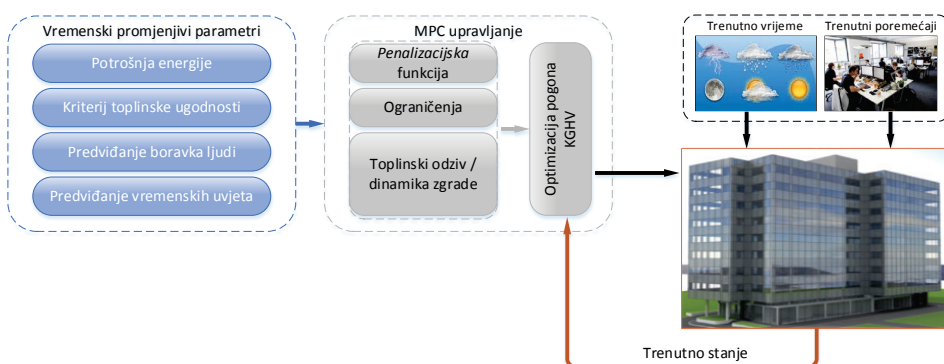
s komercijalnim CNUS-om jest činjenica da usprkos mogućnostima velikog primitka podataka nedostaje automatizirana napredna podatkovna analitika. Analitika dostupna na tržištu služi za vizualizaciju podataka o tokovima, strukturi i potrošnji energije, ali ne i za automatiziranu optimizaciju rada sustava. Prikupljeni podaci i oni koji se kontinuirano prikupljaju, primjerice o radu KGHV sustava, u komercijalno dostupnim sustavima automatizacije nerijetko su loše strukturirani i razumljivi samo visokoškoloanim stručnjacima te nemaju utjecaja na optimizaciju parametara rada (tehnoloških funkcija) tog istog sustava u realnom vremenu [3, 4].

Prikupljeni se podaci mogu iskoristiti za izradu studija o potencijalnim uštedama kroz poboljšanje sustava ili za općenitu optimizaciju osnovnih pogonskih parametara. Nadalje, jedno od mogućih rješenja za poboljšanje CNUS-a je kontinuirano praćenje parametara procesa u sustavu te automatizirani dijagnostički sustav, sličan onome kakve danas nalazimo u automobilskim sustavima. Međutim, takvo napredno upravljanje zahtjeva povećanje operabilnosti konvencionalnih sustava, odnosno sposobnosti dva ili više sustava da međusobno razmjene informaciju i koriste informaciju za poboljšanje rada cjelokupnog sustava. Ovakav način upravljanja predstavlja odmak od tzv. upravljanja niske razine (engl. *low-level control*) prema višim razinama donošenja odluka na temelju automatizirane podatkovne analitike [5, 6].

U kombinaciji s metodama za računalne simulacije u zgradama, takva rješenja naprednog upravljanja predstavljaju aktualnu temu u modernoj industriji pametnih zgrada, budući da predstavljaju potencijal za modeliranje i procjenu utjecaja raznih strategija upravljanja, čak i prije njihove primjene. Također se javlja mogućnost proaktivnih, umjesto uobičajeno reaktivnih metoda upravljanja u sustavima automatike u zgradama. Integracijom podataka dobivenih simulacijom i uvođenjem koncepta lokalnih povratnih veza u sustav, moguće je provesti sofisticirane procjene energijskih tokova, radnih parametara sustava, utjecaja na okoliš i slično, što bi moglo znatno pridonijeti kvaliteti projektiranja zgrada i upravljanja istim. Spomenuta poboljšanja mogu pridonijeti i dijagnostici pogrešaka u radu sustava u zgradama i pružanju pouzdane informacije usmjerene na donošenje relevantnih odluka. Jedna od mogućnosti koje nudi tehnologija naprednog upravljanja i problemi za njenu sustavnu implementaciju bit će predstavljeni u nastavku teksta.

2. MODELSKO PREDIKTIVNO UPRAVLJANJE

Modelsko prediktivno upravljanje (u daljnjem tekstu MPC) predstavlja vrstu naprednog upravljanja koje se počinje primjenjivati u kasnim sedamdesetim i početkom osamdesetih godina u procesnoj industriji, a posljednjih desetljeća postaje predmetom sve većeg interesa i u području zgradarstva [7-9]. Modelsko prediktivno upravljanje KGHV sustavima u zgradama podrazumijeva skupinu metoda za napredno upravljanje kojim se pogonski parametri, primjerice sustava grijanja i/ili hlađenja zgrade, kontinuirano optimiraju (obično svaki sat) za odabrani vremenski period predikcije (obično 24 sata), ovisno o predikciji vremenskih uvjeta, načinu korištenja zgrade te toplinskom odzivu zgrade prvenstveno s ciljem smanjenja ukupne potrošnje energije ili troškova energije uz istovremeno zadovoljavanje uvjeta toplinske ugodnosti. Konceptualna shema rada MPC-a prikazana je na slici 1.

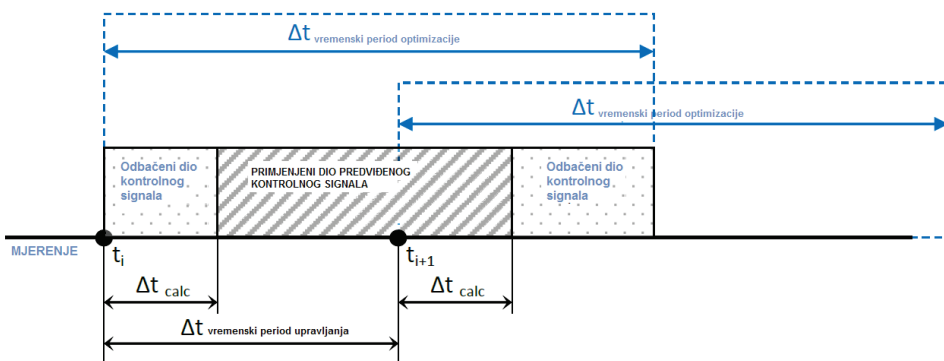


Slika 1. Koncept modelskog prediktivnog upravljanja

Optimizacija, odnosno optimizacijska funkcija kao dio naprednog upravljanja procesom temelji se na određivanju ekstrema funkcije više varijabli, odnosno, u slučaju KGHV sustava, minimuma funkcije koja opisuje primjerice potrošnju energije promatranog KGHV sustava dok se kontrolne varijable, odnosno varijable koje se mogu mijenjati tijekom optimizacije odnose na parametre rada KGHV sustava. Potrošnja energije KGHV sustava ovisna je o stanju okoliša (temperatura zraka), toplinskim gubicima i/ili dobicima u zgradi (Sunčevo zračenje, boravak ljudi u prostoru, elektronička oprema, rasvjeta i dr.) i fizikalnim karakteristikama zgrade (sastav zidova, vanjske ovojnice, orijentacije i dr.). Za realizaciju optimizacije rada sustava u vremenskom periodu predikcije potrebni su matematički modeli kojima se aproksimira tijekom stanja okoliša (temperatura zraka, vlaga, Sunčevo zračenje i dr.), raspored boravka ljudi

u prostoru i drugih relevantnih poremećajnih varijabli u navedenom vremenskom periodu predikcije. Ograničenja na dozvoljene vrijednosti varijable, odnosno domena optimizacijske funkcije ograničena je željenim uvjetima toplinske ugodnosti čiji parametri ovise o toplinskom stanju unutar zgrade koje se opisuje temeljem matematičkog modela njenog dinamičkog toplinskog odziva.

Kod ovakve vrste upravljanja, princip povratne veze ostvaruje se recidivnim vremenskim periodom. Ovu pojavu čiji koncept je prikazan na slici 2) moguće je razmotriti primjerice kroz mjerenje vrijednosti neke veličine stanja zgrade u trenutku t_i i t_{i+1} i u razmaku od $\Delta t_{\text{vremenski_period_upravljanja}}$. Mjerenjem vrijednosti u prvom trenutku, postavlja se optimizacijski problem i rješava se za odabrani vremenski period predikcije $\Delta t_{\text{vremenski_period_optimizacije}}$. Po isteku perioda Δt_{calc} koliko traje rješavanje postavljenog problema, izvodi se kontrolni signal i primjenjuje se u zgradi do rješenja novog (idućeg) optimizacijskog problema. Ovo ukazuje na činjenicu da se dio predviđenog kontrolnog signala koji se nalazi u intervalu $[t_i + \Delta t_{\text{calc}}, t_{i+1} + \Delta t_{\text{calc}}]$ primjenjuje za upravljanje, a ostali dio se odbacuje.



Slika 2. Vremenski period upravljanja i predikcije te optimizacije

Ovakvim načinom upravljanja KGHV sustavima moguće je ciljano predgrijati ili prethladiti prostor s pripadajućom masom zidova, čime se, poput u toplinskom ili rashladnom spremniku, postiže efekt akumulacije topline. Na taj način moguće je optimirati vršnu potrošnju energije, čija prekoračenja se skupo penaliziraju od strane distributera električne energije. Nadalje, budući da MPC omogućuje korištenje akumulacije topline, moguće je periode rada sustava mijenjati na način da se iskoriste povoljni uvjeti okoliša, primjerice kada vanjska temperatura zraka pridonosi većoj učinkovitosti rashladnih sustava. Isti princip moguće je

primijeniti u periodima nižih tarifa električne energije što otvara prostor za dodatne uštede [10-13].

Sustavnu implementaciju MPC-a u zgrade usporava složenost procesa u usporedbi s konvencionalnim sustavima te nedostatak eksperimentalnih ispitivanja u realnim uvjetima, zbog nedostatne mjerne opreme konvencionalnih centralno-upravljačkih sustava u zgradama i svakako administrativnih ograničenja na koje istraživači nailaze od strane vlasnika zgrade [14].

3. PREGLED TRENUTNOG STANJA PODRUČJA

3.1 Model zgrade

MPC zahtjeva prikladan matematički model upravljanog procesa koji se koristi za proračun optimalnih upravljačkih ulaznih signala. Model mora biti dovoljno precizan kako bi se njime s dovoljnom točnošću mogle predvidjeti relevantne varijable (npr. sobna temperatura), ali istovremeno i dovoljno računalno (vremenski) ne zahtjevan, kako bi se njime vršila optimizacija, dovoljno stabilna i upravljiva. Primjena softverskih alata za simulaciju energetske svojstava zgrada (npr. EnergyPlus, TrnSys, ESP-r, itd.) obično u svrhu modeliranja fizike zgrade, uobičajena je u struci (termotehnici) [15]. Ovakvi alati pružaju brojne mogućnosti za rješavanje složenih proračuna, nelinearnih problema, iterativnih procedura i sl., ali su zbog implicitne naravi neprimjenjivi za upravljanje u realnom vremenu. Ovakve modele moguće je koristiti u tzv. paralelnoj simulaciji [16] s ciljem razvijanja pojednostavljenog modela učenjem od kompleksnog modela. Istraživači uglavnom razvijaju modele manje složenosti i računalnih zahtjeva, odnosno linearne vremenski invarijantne modele, (engl. *linear time invariant*, LTI) koji su znatno prihvatljiviji za primjenu u okvirima MPC-a. Oblikovanje prikladnog LTI modela upravljanog objekta, delikatan je i složen posao čak i za iskusne inženjere te je još uvijek specifičan za pojedini promatrani objekt. Nekoliko je osnovnih pristupa pri oblikovanju LTI modela danas: a) Modeli crne kutije (engl. *black box*). Ovi modeli oblikuju se regresijskim statističko-empirijskim analizama arhiviranih podataka dobivenih mjerenjem na objektu (iz baze podataka CNUS-a) [14]. Ovaj pristup ne zahtjeva fizikalni model zgrade što značajno umanjuje opseg modeliranja i konceptualno je primjenjiv na različite tipove zgrada bez obzira na njihove karakteristike, no s druge strane sasvim ovisi o dostupnosti i valjanosti skupova podataka dobivenih

mjerenjem relevantnih veličina, (signalnih parova pobuda-odziv). Domena koju pokrivaju modeli crne kutije ovisi o broju različitih toplinskih stanja zgrade obuhvaćenih eksperimentalnim mjerenjem što predstavlja problem u realnom okruženju. Dogodi li se u radu sustava situacija koja nije pokrivena eksperimentalnim mjerenjem, zbog nepostojanja fizikalne osnove u modelima crne kutije, stabilnost sustava upravljanja postaje upitna. b) Modelima sive kutije (engl. *grey-box*) opisuje se dinamika zgrade pomoću mreže toplinskih otpora-kapaciteta (engl. *resistance-capacitance*, RC) [17-19]. Koristi se analogija s električnim krugovima u kojima temperaturni gradijenti i toplinski tok zamjenjuju električni potencijal i struju. Vjerodostojna struktura RC mreže modela prvi je korak u oblikovanju modela, a parametri se definiraju pomoću mjerenja ili simulacija detaljnim fizikalnim modelima zgrada. Prednost ovih modela leži u mogućnosti da se definira odnos između podsustava i zona, odnosno da se jednostavno definira struktura objekta, no problem definiranja parametara sustava za sada je složen postupak. Ipak, ovim modelima uvodi se određena fizikalna podloga čime se smanjuje ovisnost modela o mjerenim podacima. c) Modeli bijele kutije (engl. *white-box*) također se temelje na RC mreži, no struktura mreže s pripadajućim R i C elementima (parametrima) izvode se direktno iz detaljnih geometrijskih (realne dimenzije) i konstrukcijskih (materijali gradnje) podataka o objektu. U usporedbi s modelima sive kutije, ovi modeli temelje se na fizikalnim karakteristikama objekta, no također zahtijevaju dostupnost i obradu velike količine informacija specifičnih samo za promatrani objekt.

3.2 Poremećajne varijable

Kratkoročno predviđanje vremena (vremenska prognoza), jedna je od osnovnih poremećajnih funkcija čija točnost procjene, odnosno greška predikcije značajno utječe na rezultat primjene MPC-a. Henze i sur. [20] proveli su istraživanje utjecaja točnosti predikcije vremena na MPC. Rezultati istraživanja ukazuju da je primjenom složenog (30-dnevnog) modela za vremensku predikciju moguće ostvariti oko 20% više ušteda nego s jednostavnim (slučajnim) modelom, ali je i potrebno znatno veći period mjerenja i arhiviranja podataka. Prema mišljenju autora, optimum između potrebne količine mjerenih podataka i točnosti predikcije pruža tzv. sedmodnevna BIN metoda. S druge strane, Oldewurtel i sur. [21] koriste stohastički model MPC-a u kojem uvode predikciju vremena kao stohastički poremećaj s ograničenjem domene slučajnih događaja u optimizacijskoj funkciji.

Procjena toplinske ugodnosti u zgradama obično se temelji na tzv. osjetnoj temperaturi (engl. *operative temperature*) koja se definira kao srednja vrijednost između temperature zraka u prostoru i prosječne temperature zračenja obuhvatnih ploha prostora (engl. *mean radiant temperature*). Međutim, toplinska ugodnost je složena veličina koja ovisi o brojnim faktorima, razini fizičke aktivnosti, psihološkim i fiziološkim faktorima te u konačnici predstavlja stanje uma koje izražava zadovoljstvo toplinskim stanjem okoliša. Ocjena tog kognitivnog procesa opisuje se indeksom toplinske ugodnosti prostora zvanim predvidljivo prosječno vrednovanje (engl. *predicted mean vote*, PMV) [22-24]. Autori u [25, 26] proveli su istraživanje koristeći PMV indeks u penalizacijskoj funkciji (engl. *cost function*) prilikom formulacije MPC algoritma. Autori zaključuju kako je primjenom PMV-a za predikciju toplinske ugodnosti moguće ostvariti dodatne uštede energije, no ukazuju na dodatne probleme koji se javljaju uslijed nelinearne karakteristike indeksa toplinske ugodnosti prostora. Usporedbu nekoliko različitih formulacija primjene PMV-a u penalizacijskoj funkciji MPC-ja analizirali su Castilla i sur. [27].

3.3 Energetske uštede

Braun [19] daje pregled radova koji se tiču upravljanja KGHV sustavima uz korištenje mase objekta kao toplinskog spremnika s optimizacijskom funkcijom koja uzima u obzir promjenjivu cijenu električne energije i vršnu potrošnju sustava. Henze i Karti [28] razvijaju optimalnu strategiju upravljanja KGHV sustavom s kombiniranim aktivnim (banka leda) i pasivnim (masa zgrade) toplinskim spremnikom te zaključuju da je kombinacijom toplinskih spremnika moguće postići uštede do 57% energije u usporedbi sa sustavima s jednim ili bez spremnika topline. Chen [29] postavlja fizikalni model sustava podnog grijanja i pomoću dinamičke simulacije prediktivnog upravljanja ukazuje na prednosti ovakvog načina upravljanja u odnosu konvencionalne regulatore u smislu brzine odziva sustava, minimalnog odstupanja od postavne vrijednosti i frekvencije paljenja i gašenja sustava. Isti sustav kasnije je analizirao Cho [30] i ukazao na potencijal uštede energije primjenom MPC metode od 10% tijekom zimskih mjeseci. Ma i sur. [31] su pokazali da je primjenom MPC-ja na sustav hlađenja studentskog kampusa moguće ostvariti 19% povećanje prosječnog faktora hlađenja (engl. *energy efficiency ratio*, EER) rashladnika u usporedbi sa konvencionalnim upravljanjem. Gruber i sur. [32] utvrdili su da je zamjenom standardnih upravljačkih jedinica s onim, temeljenim na dinamičkom modelu zgrade moguće ostvariti 5-46%

ušteta energije. Bengea i sur. [33] demonstrirali su potencijalne uštede energije primjenom MPC-ja za optimizaciju rada klimatizacijskog sustava s promjenjivim volumenom zraka (engl. *variable air volume*, VAV) u poslovnoj zgradi. Ostvarene uštede energije u odnosu na konvencionalnu kontrolu rastu do čak 60%. Izuzev smanjenja potrošnje energije, prediktivnim upravljanjem moguće je pridonijeti i smanjenju vršne potrošnje [34, 35]. Smanjenjem vršne potrošnje moguće je značajno smanjiti troškove za električnu energiju, a potencijalno i troškove početne investicije za KGHV sustav ukoliko bi se analize simulacija naprednog upravljanja provodile u fazi projektiranja. Nadalje, prediktivnim je upravljanjem moguće voditi sustav s obzirom na zahtjeve distributera električne energije s ciljem uravnotežavanja odnosa kupac-distributer u elektroenergetskoj mreži. Analiza trenutnog opterećenja elektroenergetske mreže i smanjenje vršne potrošnje sustava kupca prema zahtjevu operatera bilo je predmetom simulacija koje su proveli Oldewurtel i sur. [36] s ciljem optimiranja profila opterećenja sustava na strani operatera. Ma i sur. [37] analizirali su model upravljanja ponuda-potražnja u kojem je MPC primijenjen na rashladni sustav višezonske poslovne zgrade koji rezultira optimalnim prethlađivanjem mase zgrade u vrijeme niskog opterećenja elektroenergetske mreže te autonomnim pasivnim hlađenjem tijekom perioda vršnog opterećenja iste mreže.

4. PLAN ISTRAŽIVANJA

Planom istraživanja koje provodi autor, obuhvaćeno je provođenje pregleda trenutnog stanja razvoja predmetnog područja, analiza i razvoj računalnog algoritma za MPC te validacija i ugađanje istog kroz sustavna mjerenja na pilot zgradi. Struktura istraživanja predložena je kroz slijedeće elemente:

4.1 Istraživanje i razvoj računalnog algoritma za MPC

Prije izrade računalnog modela proveden je detaljan pregled trenutnog stanja područja istraživanja s naglaskom na identifikaciju ključnih problema za primjenu MPC-a u realnom okruženju. Potom se pristupa analizi trenutno najzastupljenijih matematičkih metoda za računalnu simulaciju dinamičkog toplinskog odziva zgrade s obzirom na poremećajne funkcije u cilju oblikovanja unaprijeđenog modela, adekvatnog za preliminarne analize koje prethode izradi pojednostavljenog modela praktičnog za implementaciju u MPC algoritam (od modela se zahtjeva smanjenje potrebnog računalnog

vremena uz istovremeno zadržavanje dovoljne točnosti predikcije). Nadalje slijedi razvoj matematičkih modela za dinamičku simulaciju pogonskih parametara sustava grijanja, hlađenja i ventilacije optimiranih za implementaciju u MPC algoritam. Optimizacija modela provest će se temeljem komparativne analize stvarnih vremenskih uvjeta izmjerenih na lokaciji i onih predviđenih kratkoročnom prognozom prema DHMZ-u s rezultatima razvijenog modela za kratkoročno predviđanje vremena.

4.2 Eksperimentalna mjerenja na pilot projektima

Eksperimentalnim mjerenjima relevantnih veličina na pilot zgradi i analizom rezultata planira se provesti validacija modela navedenih u prvoj točki ovog istraživačkog rada. Postupku mjerenja prethodi razvoj metodologije mjerenja koja sadržava analizu i odabir relevantnih veličina koje je potrebno mjeriti, analizu adekvatnog mjernog intervala i mjernog perioda te strategiju upravljanja KGHV sustavom (oblikovanje poremećajne funkcije KGHV sustava) tijekom perioda mjerenja. Od relevantnih veličina mjeri se temperatura vanjskog zraka i intenzitet ukupnog Sunčevog zračenja na lokaciji pilot zgrade, temperature zraka u prostorijama, temperature zraka na usisnoj i isturjnoj rešetci te brzina vrtnje ventilatora na ventilokonvektorima instaliranim u svakoj prostoriji, intenzitet osvijetljenosti prostora te parametri rada termotehničkih sustava za isporuku ogrjevnog ili rashladnog učina.

5. ZAKLJUČAK

Napredno upravljanje KGHV sustavima u zgradama rezultat kojeg je kontinuirana optimizacija pogonskih parametara sustava predstavlja značajan potencijal za smanjenje potrošnje energije i ostvarivanje financijskih ušteda. Međutim, napredno upravljanje zahtjeva relativno kompleksan mehanički i upravljački sustav, što znatno otežava široku primjenu odnosno tehnologije, pa unatoč tome što je potencijal predstavljen u mnogobrojnim znanstvenim radovima, problematika primjene naprednog upravljanja u realnim uvjetima vrlo je slabo istraženo područje. Metodologija te računalni algoritmi koji su potrebni za sustavno uvođenje takve vrste upravljanja u realnu zgradu još uvijek nisu razvijeni prvenstveno radi poteškoća oko izvođenja eksperimentalnih mjerenja u realnim uvjetima sa stvarnim korisnicima. Ovim istraživanjem želi se, na tipičnoj poslovnoj zgradi u Hrvatskoj, razviti metodologija primjene modelskog prediktivnog upravljanja KGHV sustavima te pokazati potencijal ove tehnologije i njenu primjenjivost na druge sustave.

BIBLIOGRAFIJA

1. UN, *Report of the United nations conference on environment and development*, UNCED, Rio de Janeiro, 1992.
2. EK, Priopćenje komisije. *Europa 2020: Europska strategija za pametan, održiv i uključiv rast*, EU komisija, 2010.
3. TIAX LLC., *Energy Impact of commercial building controls and performance diagnostics*, Cambridge: Tiax, LLC, 2005.
4. Samouhos S., *Building condition monitoring*, Ph. D. thesis, Massachusetts Institute of technology, 2010
5. Harris D., *Energy management in buildings*, Spon Press, USA, 2012.
6. Hui, S. C. M., *Latest trends in building automation and control systems*, Intelligent facility management and intelligent transport, CAI conference, Hong Kong, 2007.
7. Maciejowski J., *Predictive control with constraints*, Prentice Hall, 2001.
8. Richalet J. et. al., *Model predictive heuristic control: Applications to industrial processes*, Automatica 14.5, P. 413–428., 1978.
9. Kwon W., Bruckstein A., Kailath T., *Stabilizing state-feedback design via the moving horizon method*, International journal of control 37.3, P. 631–643., 2005.
10. Braun J.E., *Reducing energy costs and peak electrical demand through optimal control of building thermal storage*, ASHRAE Transactions, Vol. 96, 1990.
11. Gayeski N.T., Armstrong P.R., Norford L.K., *Predictive pre-cooling of thermo-active building systems with low-lift chillers*, HVAC&R Research (Special issue on optimization), 2011.
12. Armstrong P.R., Leeb S.B., Norford L.K., *Control with building mass - Part II: Simulation*, ASHRAE, PNNL, MIT Cambridge, 2006.
13. Lee, Braun J.E., *Development and application of an inverse building model for demand response in small commercial buildings*, SimBuild, IBPSA-USA National conference, 2004. [36] Orosa J. A., Oliveira A. C., *Software tools for HVAC research*, Advances in Engineering Software 42.10, pp. 846–851., 2011.
14. Privara S., Váňa Z., Gyalistras D., Cigler J., Sagerschnig C., Morari M., Ferkl L., *Modeling and Identification of a Large Multi-Zone Office Building*, IEEE Multi-conference on Systems and Control. IEEE, pp. 55–60., 2011.
15. Orosa J. A., Oliveira A. C., *Software tools for HVAC research*, Advances in Engineering Software 42.10, pp. 846–851., 2011.

16. Wetter M., *Co-simulation of building energy and control systems with the Building Controls Virtual Test Bed*, Journal of Building Performance Simulation 4.3, pp. 185–203., 2011.
17. Ma Y., Kelman A., Daly A., Borrelli F., *Predictive Control for Energy Efficient Buildings with Thermal Storage: Modeling, Stimulation, and Experiments*, Control Systems, IEEE 32.1, pp. 44–64., 2012.
18. Gyalistras D., Gwerder M., *Use of weather and occupancy forecasts for optimal building climate control (OptiControl): Two years progress report*, Tech. rep. ETH Zurich, Switzerland and Siemens Building Technologies Division, Siemens Switzerland Ltd., Zug, Switzerland, 2009.
19. Verhelst C., Logist F., Impe J. V., Helsen L., *Study of the optimal control problem formulation for modulating air-to-water heat pumps connected to a residential floor heating system*, Energy and Buildings 45, pp. 43–53., 2012.
20. Oldewurtel F., Jones C., Morari M., *A tractable approximation of chance constrained stochastic MPC based on a disturbance feedback*, 47th IEEE Conference on Decision and Control, CDC., pp. 4731–4736., 2008.
21. Henze G., Kalz D., Liu S., Felsmann C., *Experimental analysis of modelbased predictive optimal control for active and passive building thermal storage inventory*, HVAC & Research 11.2, pp. 189–213., 2005.
22. Fanger P. O., *Thermal Comfort*, Danish Technical Press, Copenhagen, 1970.
23. ISO7730:2005, *Ergonomics of the thermal environment-analytical determination and interpretation of thermal comfort using calculation of PMV and PPD indices and local thermal comfort criteria*, International Organization for Standardization, 2005.
24. ASHRAE Fundamentals, ASHRAE Handbook Series, American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., Atlanta, USA, 2005.
25. Freire R., Oliveira G., Mendes N., *Predictive controllers for thermal comfort optimization and energy savings*, Energy and Buildings 40.7, pp. 1353–1365., 2008.
26. Goyal, Siddharth, Herbert A. Ingley, Barooah P., *Occupancy-Based Zone-Climate Control for Energy-Efficient Buildings: Complexity vs. Performance*, Applied Energy 106, 2013.
27. Castilla M., Álvarez J., Berenguel M., Rodríguez F., Guzmán J., Pérez M., *A comparison of thermal comfort predictive control strategies*, Energy and Buildings 43.10, pp. 2737–2746., 2011.

28. Gregor P. Henze, Clemens Felsmann, Gottfried Knabe, *Evaluation of optimal control for active and passive building thermal storage*, International Journal of Thermal Sciences, Volume 43, Issue 2, February 2004, Pages 173-183
29. Chen T., *Application of adaptive predictive control to a floor heating system with a large thermal lag*, Energy and Buildings 34.1, pp. 45–51., 2002.
30. Cho, *Predictive control of intermittently operated radiant floor heating systems*, Energy Conversion and Management 44.8, pp. 1333–1342., 2003.
31. Ma Y. et.al., *Model predictive control for the operation of building cooling systems*, Lawrence Berkeley national laboratory (LBNL), LBNL-3905E, 2010.
32. Gruber M. et.al., *Model-based controllers for indoor climate control in office buildings – Complexity and performance evaluation*, Energy and buildings, Vol. 68, Part A, P. 213-222, 2014.
33. Bengea S. C. et.al., *Model predictive control for mid-size commercial building HVAC: Implementation, results and energy savings*, HVAC Research, Vol. 20(1), P. 121-135., 2014.
34. Rijksen D., Wisse C., Schijndel van A., *Reducing peak requirements for cooling by using thermally activated building systems*, Energy and Buildings 42.3, pp. 298–304. 2010.
35. Katipamula S., Armstrong P. R., Wang W., Fernandez N., Cho H., *Efficient Low-Lift Cooling with Radiant Distribution, Thermal Storage and Variable-Speed Chiller Controls*, Proceedings of 10th Rehva World Congress, Clima, 2010.
36. Oldewurtel F., Ulbig A., Parisio A., Andersson G., Morari M., *Reducing peak electricity demand in building climate control using real-time pricing and model predictive control*, 49th IEEE Conference on Decision and Control (CDC)., pp. 1927–1932., 2010.
37. Ma J., Qin S., Li B., Salsbury T., *Economic model predictive control for building energy systems*, Innovative Smart Grid Technologies (ISGT), 2011 IEEE PES. IEEE., pp. 1–6., 2011.